

改进 GA-BPNN 在短期电力负荷预测中的应用

张 勇, 杨 云

ZHANG Yong, YANG Yun

陕西科技大学 电气与信息工程学院, 西安 710021

Department of Electrical and Information, Shaan'xi University of Science & Technology, Xi'an 710021, China

E-mail: helloaward@126.com

ZHANG Yong, YANG Yun. Research of short-term power load forecasting based on improved GA-BP neural network model. *Computer Engineering and Applications*, 2009, 45(13): 223-226.

Abstract: In order to avoid the complex forecasting model of short-term load by traditional methods, the hybrid algorithm which combines improved GA with BP is used to train artificial neural network for carrying on the simulation forecast to the short-term power load according to the past power load data. The results show that the defects of conventional BP algorithm, i.e., easy to fall into local minimum, slow convergence speed of the weight value of learning network, and that of GA, i.e., the training speed is too slow when GA is used to train the neural network effectively improved by itself, are effectively improved by the hybrid algorithm and the hybrid algorithm possesses faster convergence speed and higher calculation accuracy.

Key words: short-term load; GA (genetic algorithm); artificial neural network; BP (error back propagation); forecasting

摘 要: 为了避免传统方法预测短期电力负荷建模复杂性, 将改进遗传算法(GA)和误差反向传播(BP)算法相结合构成的混合算法用于训练人工神经网络, 结合电力负荷历史数据, 对短期电力负荷进行仿真预测。仿真结果表明, 该混合算法有效地解决了常规BP算法学习网络权值收敛速度慢、易陷入局部极小和GA算法独立训练神经网络速度缓慢等问题, 具有较快的收敛速度和较高的预测精度。

关键词: 短期电力负荷; 遗传算法; 人工神经网络; 反向传播; 预测

DOI: 10.3778/j.issn.1002-8331.2009.13.066 **文章编号:** 1002-8331(2009)13-0223-04 **文献标识码:** A **中图分类号:** TP183; TM751

目前, 有许多人工智能方法应用于短期负荷预测, 其中最广泛的是反向传播BP的多层前馈神经网络^[1]。与传统的负荷预测方法相比, 实际应用中BP网络具有很好的预测效果, 因此备受重视。BP网络的突出优点是, 通过对样本集的学习, 可以获得输入、输出之间存在的复杂非线性映射关系, 还可以方便地处理复杂的各类输入。如天气、温度等影响因素。BP网络的训练通常是一个复杂的大规模优化问题, 而BP算法本身存在容易陷入局部极小值、收敛速度慢、迭代时间长等一些固有缺陷, 因此影响了BP神经网络预测模型的精度^[2-3]。

本文将改进遗传算法和误差反向传播算法相结合构成的混合算法用于训练短期电力负荷预测的神经网络模型, 取得良好应用效果。

1 BP神经网络改进算法

BP神经网络是一种单向传播的多层神经网络, 如图1所示。

它可看成是一个从输入到输出的高度非线性映射^[4], 即




图1 BP网络结构

$$F: R^n \rightarrow R^m \quad F(X) = Y \quad (1)$$

一般由输入层、隐含层、输出层组成^[5]。同层节点中没有任何耦合, 每一层节点的输出只影响下一层节点的输入^[6]。BP算法的学习过程分为正向传播和反向传播过程。如果正向传播输出的误差达不到预期精度, 则沿误差的负梯度方向反复修改各层神经元的权值和阈值, 直至网络全局误差信号最小。由于传统BP算法基于梯度下降法的, 而梯度下降法通常具有收敛速度慢、易陷入局部极小值和振荡等缺点, 所以将BP算法进行了改进。

在权值调节中采用增加动量因子 α 和步长 η 。通过选择合适的 α , 可以避免每一步权值修正过大而出现的震荡现象。权

基金项目: 国家自然科学基金(the National Natural Science Foundation of China under Grant No.59732050); 陕西省自然科学基金(the Natural Science Foundation of Shaanxi Province of China under Grant No.SJ08E103)。

作者简介: 张勇(1980-), 男, 硕士在读, 研究方向: 信息技术处理; 杨云(1965-), 女, 教授, 博士在读, 研究方向: 嵌入式系统及应用, 数据仓库数据挖掘, 信息技术处理。

收稿日期: 2008-10-07 **修回日期:** 2008-12-12

值修正方法如下:

$$\Delta\omega_{ji}^{(l)}(n) = (1-\alpha)\eta\delta_{pj}^{(l)}(n)o_{pi}^{(l-1)}(n) + \alpha\Delta\omega_{ji}^{(l)}(n-1) \quad (2)$$

式(2)中, $\Delta\omega_{ji}^{(l)}(n)$ 为第 l 层第 j 个神经元与上一层第 i 神经元之间的连接权的第 n 部修正值; α 为动量因子, $\alpha \in [0, 1]$ 。从式(2)可以看出, $\Delta\omega_{ji}^{(l)}(n)$ 不仅决定于 BP 算法中当前修正值 $\eta\delta_{pj}^{(l)}(n)o_{pi}^{(l-1)}(n)$, 还与 α 以及上一部权值修正有关。当 α 为 0 时, 权值变化完全由 BP 算法决定, 当 α 为 1 时, 新的权值变化等于上一次权值的变化。

而 η 的选值与网络学习性能密切相关, η 代表了权值修正的幅度。对于 η 通过采用自适应学习率算法来调节, 当新的调节误差比设定的最大调节误差大时, 将 η 降低, 即将上一步 η 乘以一个下降系数 d_m ($0 < d_m < 1$), 并将 α 置零; 当新的调节误差比上一步调节误差小时, 将 η 增加, 即将上一步 η 乘以一个增加系数 i_m ($i_m > 1$)。自适应学习率算法降低了网络对误差曲面局部细节的敏感性, 能有效地抑制网络陷于局部极小, 提高了学习速度并增强了算法的可靠性^[7]。

2 遗传算法的改进

采用遗传算法求解实际问题时, 即希望在广泛的空间上进行搜索, 又希望尽快收敛于寻优目标。必须对传统的遗传算法进行调整和改进才能两者兼顾^[8]。在应用遗传算法解决电力负荷预测问题时, 由于无需目标函数连续可微, 用户用电量和成本、天气可以不作任何假设而直接操作, 而且其鲁棒性、并行性等优点在此也可以得到充分发挥。但当用简单遗传算法处理一些大系统时, 还存在一些不足之处。其中最主要的是搜索效率不高和过早收敛。针对以上问题采用了多种改进手段。

(1) 杂交率和变样率的自适应调整 杂交率 P_c 和变样率 P_m 的自适应调整是提高搜索效率的有效方法之一。遗传操作过程中调整杂交率和变样率公式如下:

$$P_c = \begin{cases} P_{c1} - \frac{(P_{c1} - P_{c2})(f' - f_{avg})}{f_{max} - f_{avg}} & f' \geq f_{avg} \\ P_{c1} & f' < f_{avg} \end{cases} \quad (3)$$

$$P_m = \begin{cases} P_{m1} - \frac{(P_{m1} - P_{m2})(f - f_{avg})}{f_{max} - f_{avg}} & f \geq f_{avg} \\ P_{m1} & f < f_{avg} \end{cases} \quad (4)$$

式(3)(4)中 P_{c1} 和 P_{m1} 分别为适应值低于种群平均适应值的个体的交叉率和变异率, $P_{c1}=0.9, P_{m1}=0.1$; P_{c2} 和 P_{m2} 分别为每代群体中最优个体的交叉率和变异率, $P_{c2}=0.6, P_{m2}=0.001$; f' 为杂交运算前父代双亲中较大的适应值; f 为变异个体的适应值。调整中减小劣质个体(适应值高于种群中的平均适应值)的 P_c 和 P_m , 可促使遗传计算尽快收敛, 增大适应值低于种群中的平均适应值的个体的 P_c 和 P_m , 可避免遗传算法陷入局部极小值。

(2) 加快收敛速度的措施

本文对适应度进行调节以避免遗传算法发生“过早收敛”和搜索后期的“停滞现象”的出现^[9]。种群适应度的平均值 f_{avg} 和方差 δ 分别定义为:

$$f_{avg} = \frac{\sum_{i=1}^N f_i}{N} \quad (5)$$

$$\delta = \sqrt{\frac{\sum_{i=1}^N (f_i - f_{avg})^2}{N}} \quad (6)$$

再将各适应度调整如下:

$$f'_i = f_i + (f_{avg} - c) \times \delta \quad (7)$$

式中 f_i 为个体 i 的适应值; N 为群体规模; f'_i 为调整后个体 i 的适应值。 c 为系数, 是 1~5 之间的整数。

如调整后的适应度小于 0, 则令其为 0。遗传算法中适应度是衡量个体优劣的标志^[10]。根据适应度以某种概率选择个体, 个体适应度愈高, 它被重复选择的可能性愈大, 而适应度小的个体往往未能选中, 从而实现“优胜劣汰”。

(3) 自适应正态变异算子

采用自适应正态变异算子, 使变异的范围与变异个体的性能联系起来, 即适应值较大的变异个体在较小范围内变异, 适应值较大的变异个体在较大范围内变异。引入变异温度的概念^[10], 这一概念类似于模拟退火算法中的温度, 设 $s = (v_1, v_2, \dots, v_n)^T$ 是权系数解空间的一个矢量, $f(s)$ 是它的适应值, f_{max} 是最大适应值, 则其变异温度可定义为:

$$t = 1 - \frac{f(s)}{f_{max}}$$

实际操作中可以将当前群体中最大的适应值作为 f_{max} 。

正态变异算法最初是在进化策略中得以使用的。设 $s = (v_1, v_2, \dots, v_n)^T$ 是父代权矢量, 选择分量 v_k 进行变异, 其变化范围为 $[a_k, b_k]$, 则变异后的权值矢量为 $s' = (v_1, v_2, \dots, v_{k-1}, v_k', \dots, v_n)^T$ 其中 v_k' 服从 $N(v_k, \delta^2(T))$ 的正态分布。经过反复调试采用 $\delta^2(T) = \exp(T) - 1$ 。这样定义的自适应变异算法能保护适应度较好的解, 使搜索在较小的领域内进行; 而对于适应度不好的解, 搜索的领域较大。这样就使变异根据解的质量自适应调整搜索区域, 从而明显提高搜索能力。由于神经网络的权值修正量可正可负, 因此自适应正态变异算子比较适合于神经网络权值学习。

3 GA-BP 混合算法的实现

将改进的 GA 与 BP 神经网络算法结合起来形成一种混合算法。在混合算法中, 首先将神经网络的权向量和阈值编码成一个字符串, 构成一个实数数组, 于是产生 $[-1, 1]$ 之间的若干组随机数(个体)作为遗传算法的初始种群。假设群体规模为 N , 即共有 N 条染色体。在遗传操作的每一代中, 对每一条染色体进行编码, 计算出权矢量和阈值, 并求出每条染色体相应的实际输出值 y_k ($k=1, 2, \dots, m$), m 为神经网络输入输出的样本对数, 则第 i ($i=1, 2, \dots, N$) 条染色体的适应度为:

$$f_i = 1 / \exp(E_i) \quad (8)$$

式(8)中 $E_i = \sum_{k=1}^n (y_k - t_k)^2$, t_k 为神经网络的目标输出。采用指数形式使得误差平方和大的个体适应度变差。混合算法的操作步骤如下:

(1) 根据给定的输入、输出训练样本集, 设计神经网络的输入层、隐含层和输出层的解点数, 确定神经网络的拓扑结构。

(2) 设定遗传算法的具体规模 N , 设置 GA 的 P_c 和 P_m 及自适应调整法, 随机产生 $[-1, 1]$ 间的 N 条染色体作为初始种群。

(3) 对种群中的染色体进行译码并计算第 i 条染色体的误差平方和 E_i 和适应度 f_i 的值。

(4) 计算种群中的 f_{\max} 和 f_{avg} , 并将适应度为 f_{\max} 的染色体对应的神经网络权值矢量和阈值记为 B_1 , 判断 f_{\max} 是否满足精度要求, 满足则转向步骤(8), 否则转向步骤(5)。

(5) 进行遗传选择操作, 并对 P_c 和 P_m 做自适应调整, 采用改进的遗传算子进行遗传操作, 形成新一代群体。

(6) 对 B_1 的权值作反向传播计算, 求出各层神经元的误差信号, 用 BP 算法的调整公式对 B_1 的权值调整若干次后得到 B_2 。

(7) 从父代群体和新一代群体及 B_2 中选出 N 个较好的染色体形成下一代的新群体, 转向步骤(3)。

(8) 对适应度 f_{\max} 的染色体进行译码, 得到神经网络的权值矢量和阈值, 结束算法。

4 短期电力负荷预测模型及其应用

4.1 训练样本的数据处理

影响电力负荷预测的因素主要由历史电力负荷以及相应的天气因素、日期类型组成, 为提高预测精度, 将这些因素进行归一化处理, 作为神经网络的输入矢量。预测日高低负荷作为输出量。 t 时刻负荷数据 X_t 采用下面归一化公式换算:

$$X'_t = \frac{X_t - X_{\min}}{X_{\max} - X_{\min}} \quad (t=1, 2, \dots, 24) \quad (9)$$

输出层采用公式重新换回实际的负荷值, 其公式为:

$$X_t = (X_{\max} - X_{\min})X'_t + X_{\min} \quad (10)$$

式中: X_{\max} 和 X_{\min} 分别表示训练样本集合中电力负荷的最大值和最小值。

(1) 气温的量化: 气温的隶属度函数分别按低温、中温和高温采用偏小型、中间型和偏大型梯形分布。

低温隶属函数为:

$$u_{t1} = \begin{cases} 0 & (t > 10) \\ \frac{10-t}{10-0} & (0 \leq t \leq 10) \\ 1 & (t < 10) \end{cases} \quad (11)$$

中温隶属函数为:

$$u_{t2} = \begin{cases} 0 & (t > 25 \text{ 或 } t < 5) \\ \frac{t-5}{15-5} & (5 \leq t \leq 15) \\ \frac{25-t}{25-15} & (15 \leq t \leq 25) \end{cases} \quad (12)$$

高温的隶属度函数为:

$$u_{t3} = \begin{cases} 0 & (t < 20) \\ \frac{t-20}{40-20} & (20 \leq t \leq 40) \\ 1 & (t > 40) \end{cases} \quad (13)$$

将同类型日的最高气温 t_h 分别代入以上公式, 计算得到 t_h 对应的低、中、高三个状态的隶属度。根据隶属度最大原则, 可知 t_h 所属的模糊集。对于最低温度, 可按照同样方法求出三个相应的隶属状态及取值。

(2) 天气情况的量化。天气情况可用语言变量进行描述, 如表 1, 将天气这个模糊量给定量化系数。

对于日期取值可根据具体情况和需求单独建模。

4.2 网络训练

网络中有 14 个输入节点和一个输出节点, 神经网络输入输出的信息如表 2。

选出 20 组数据作为学习样本, 分别用变步长寻优、动量系

表 1 天气情况量化系数

天气情况	量化系数	
晴	0.0	
多云	0.2	
阴	0.4	
	降雨量/mm	量化系数
雨	0	0
	0~15	0.2
	15~30	0.3
	30~50	0.5
	50~80	0.7
	80~120	0.9
	>120	1.0

表 2 预测日 t 时刻最高(低)负荷的神经网络输入输出量

神经元	相应量	神经元	相应量
输入	1 前一天 t 时刻最高(低)负荷	8 前两天 t 时刻最低温度	
	2 前一天 t 时刻最高温度	9 前两天 t 时刻天气情况	
	3 前一天 t 时刻最低温度	10 前两天 t 时刻日期类型	
	4 前一天 t 时刻天气状况	11 预测日 t 时刻最高温度	
	5 前一天 t 时刻日期类型	12 预测日 t 时刻最低温度	
	6 前两天 t 时刻最高(低)负荷	13 预测日 t 时刻天气情况	
	7 前两天 t 时刻最高温度	14 预测日 t 时刻日期类型	
输出	15 预测日 t 时刻最高(低)负荷		

数为 0.85 的 GA-BP 混合算法和 BP 算法对网络进行训练, 反复调试后两种算法的训练结果见表 3。

表 3 不同算法的训练结果比较

算法	最优训练代数	隐层神经元数	平均最大适应度	训练时间/s	平均泛化误差
BP 算法	3 750	15	13.609	307.05	1.572 4
GA-BP 混合算法	729	10	5.821	78.61	0.783 5

由表 3 实验结果与预测结果的对比分析中可以知道, GA-BP 学习算法预测电力负荷性能的有效性和准确性, 经计算, 使用寿命预测的平均误差小于 0.8%, 可以满足实际中的预测精度。传统 BP 网络和基于动量修改法的改进 BP 网络预测试验结果表明, 其预测精度比 GA-BP 要差得多。图 2 给出了 BP 网络学习训练时的收敛性能曲线。从图中可以看出, 传统的 BP 算法收敛速度比较慢, 容易陷入局部极小值而在迭代次数为 2 500 时没有收敛(曲线 1); 曲线 2 描述的是基于动量修改法的改进型 BP 网络的收敛过程; 而本文基于进化处理的 BP 算法(曲线 3)收敛速度明显比以往算法快, 并能有效地避免局部极小, 具有很高的实用价值。对于同样的一组学习样本集, 相同层次结构、不同算法的神经网络应用 GA-BP 混合算法训练的时间比常规 BP 算法的时间短且误差精度高。

4.3 网络验证及方针实例分析

为了验证 GA-BP 混合算法训练短期负荷预测神经网络的有效性, 本文选取湖北石首某地区的 2006 年 5 月至 2007 年 10 月的历史电力负荷数据和该地区对应日期、天气数据作为学习样本, 对神经网络进行训练仿真, 再根据训练好的神经网络来预测 2008 年 5 月 8 日(星期四)的负荷, 并将其与 BP 神经网络预测结果比较。如表 4。

5 结束语

BP 算法可弥补 GA 算法局部搜索能力的不足, GA 算法的全局搜索可避免陷入局部极小, 将两者结合起来训练神经网络




图2 神经网络学习收敛性能

表4 负荷预测结果

时刻	实际负荷/MW	改进 GA-BP 网络		BP 神经网络	
		预测值/MW	误差/(%)	预测值/MW	误差/(%)
1	648.95	652.41	0.53	662.30	2.05
3	596.86	602.33	0.91	610.12	1.29
5	593.23	596.31	0.52	587.03	-1.56
7	788.52	783.46	-0.64	772.61	-2.01
9	1 000.51	993.84	-0.67	1 012.03	1.51
11	1 205.87	1 195.76	-0.84	1 213.96	0.67
13	896.13	902.98	0.76	883.12	-1.45
15	979.41	976.83	-0.26	996.22	1.71
17	989.17	997.53	0.85	1 006.36	1.73
19	1 089.87	1 080.62	-0.85	1 068.71	-1.94
21	1 017.67	1 026.92	0.90	1 048.02	2.98
23	886.31	893.95	0.86	862.51	2.68

可较好地解决 BP 算法易陷入局部极小而遗传算法搜索时间长这一矛盾。

(上接 193 页)

度偏差同时存在时,透视变换得到的校正图像明显好于控制点变换得到的校正图像,且两者之间的误差会随畸变程度逐渐变大。

(4)图像校正过程中,由于控制变换的算法特性,采集光轴与图样的角度偏差和采集平面与图样的角度偏差同时存在,则拍摄时产生的透视畸变无法完全恢复到真实图像,当人眼以一定角度观察图片时会有明显的压缩或拉伸感,经过控制变换校正的图片仍保留这种特性,如图 4 所示可见透视畸变在控制变换图像校正后仍保留有压缩特征,而通过透视变换校正的则还原了真实图像。这样,图像的不同方位的压缩情况不同,会使得采用控制点变换得到的校正图像行列模块有上下波动,造成定位不准确,识别失败。




图4 QR 定位区域校正效果

实际应用中,采集的二维条码图像一般都会出现采集光轴与图样的角度偏差和采集平面与图样的角度偏差同时存在的几何失真。当畸变不严重且条码信息密度低、信息量小时采用控制点变换来校正图像可以基本实现条码的正确识别,但当条码信息密度高、信息容量大(如较高版本的 QR Code、Data-Matrix、Code93、龙贝码)时,光学系统的点扩展函数的影响将大于条码模块的宽度,采用控制点变换校正后的图像将仍有少许

混合算法的计算精度、收敛速度及计算稳定性较常规 BP 算法及遗传算法有明显提高,对输入输出关系复杂的训练样本具有较好收敛效果。它提高了预测的可靠性,推广了神经网络应用于短期电力负荷预测的实用性。

参考文献:

- [1] Khotanzad A. ASTLF-A neural network based electric load forecasting system[J]. IEEE Trans on Neural Network, 2005, 8(4): 835-846.
- [2] 郑德忠, 葛文谦. 基于数值优化的改进 BP 算法在旋转机械故障诊断中的应用[J]. 传感技术学报, 2005, 18(3): 510-513.
- [3] 蔡虹, 叶水生. 一种基于模糊聚类的组合 BP 网络挖掘方法[J]. 计算机工程与应用, 2005, 41(36): 83-85.
- [4] 向嵩, 王雨. BP 改进算法神经网络的保护渣性能预测模型[J]. 炼钢, 2006, 22(3): 45-48.
- [5] 左云波, 张怀存. 一种改进的 BP 网络快速算法[J]. 北京机械工业学院学报, 2005, 20(1): 31-33.
- [6] Kong Fansen, Chen Rubeng. A combined method for triplex pump fault diagnosis based on wavelet transform, fuzzy logic and neuron-net-works[J]. Mechanical System and Signal Processing, 2004, (18): 161-168.
- [7] 董长虹. Matlab 神经网络与应用[M]. 北京: 国防工业出版社, 2005.
- [8] 王小平, 曹立明. 遗传算法[M]. 西安: 西安交通大学出版社, 2006.
- [9] 潘正君, 康立山. 演化计算[M]. 北京: 清华大学出版社, 2006.
- [10] 云庆夏. 进化算法[M]. 北京: 冶金工业出版社, 2007.

畸变,单纯的几何空间恢复使得模块的定位出现扭曲,距离控制点越远,畸变越严重,定位偏离情况也越明显,依靠模块排列储存信息的 QR 码亦将出现信息识别错误,造成解码错误或解码失败。

实验表明,采用透视变换方法进行条码图像的校正可获得良好的效果,图像畸变得到了较好的恢复,高密度条码模块的定位精确度有很大提高,满足了高密度条码图像在日益广泛的实际应用中的需要。由于两种算法的计算复杂度相当,透视变换方法相比控制变换方法更具明显的优势,不论条码模块密度大小,拍摄时产生的畸变均可得到良好的恢复效果,在条码识别领域可替代控制变换方法完成图像的校正工作。

参考文献:

- [1] Slama C C. Manual of photogrammetry[M]. Washington DC: American Society of Photogrammetry, 1980: 1-5.
- [2] Niu Yan. Discussion about perspective transform[J]. Journal of Computer-Aided Design & Computer Graphics, 2001, 13(6): 549-551.
- [3] 刘慧娟. 快速响应码图像的全方位识别[J]. 仪器仪表学报, 2006, 27(4): 376-379.
- [4] Sriram T, Rao V K. Application of barcode technology in automated storage & retrieval systems[C]. // Industrial Electronics Conference Proceedings, Taipei, 1996: 5-10.
- [5] Guan Ling. Frontmatter multimedia image and video processing[M]. Boca Raton: CRC Press LLC, 2001.
- [6] Tekalp A M. Digital video processing[M]. 2 版. 北京: 清华大学出版社, 1998: 165-166.
- [7] Gonzalez R C. Digital image processing[M]. 2 版. 北京: 电子工业出版社, 2003: 215-216.